

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra informatiky

Analýza biomedicínských snímků magnetické rezonance při roztroušené skleróze

Analysis of Biomedical Magnetic Resonance Images with Multiple Sclerosis

2017

Marek Oškrobaný

Zadání bakalářské práce

Student:

Marek Oškrobaný

Studijní program:

B2647 Informační a komunikační technologie

Studijní obor:

2612R025 Informatika a výpočetní technika

Téma:

**Analýza biomedicínských snímků magnetické rezonance při roztroušené
skleróze
Analysis of Biomedical Magnetic Resonance Images with Multiple
Sclerosis**

Jazyk vypracování:

čeština

Zásady pro vypracování:

Cílem diplomové práce je návrh a realizace modulu v systému FOTOM NG na hodnocení série snímků roztroušené sklerózy z magnetické rezonance za účelem automatického návrhu použití segmentačních metod a jejich parametrů nastavení.

1. Seznamte se s problematikou počítačového zpracování fotografií a různých segmentačních metod.
2. Seznamte se s prostředím platformy NetBeans a programovacím jazykem JAVA.
3. Seznamte se s fotogrammetrickým systémem FOTOM 2008 a FOTOM NG.
4. Navrhněte nový modul, který na základě vstupní série medicínských snímků vybere nejvhodnější metodu segmentace, nastaví parametry a její provedení.
5. Navržený modul implementujte v systému FOTOM NG a proveďte zhodnocení dosažených výsledků.
6. Vypracujte uživatelskou příručku a programátorskou dokumentaci.

Seznam doporučené odborné literatury:

- [1] GONZALEZ, Rafael C a Richard E WOODS. Digital image processing. 3rd ed. Upper Saddle River: Pearson, c2008, xxii, 954 s. ISBN 01-316-8728-X.
- [2] JAN, Jiří. Medical image processing, reconstruction and restoration: concepts and methods. Boca Raton: Taylor, 2006, 730 s. ISBN 08-247-5849-8.
- [3] LIČEV, Lačezar. Analýza, modelování, rozpoznávání a vizualizace procesu měření objektů na snímcích. Vyd. 1. Brno: Computer Press, 2010, 125 s. ISBN 978-80-251-3296-8.
- [4] HEROUT, Pavel. Učebnice jazyka Java. 5., rozš. vyd. České Budějovice: Kopp, 2010, 386 s. ISBN 978-80-7232-398-2.
- [5] BÖCK, Heiko. The definitive guide to NetBeans platform. Berkeley: Apress, c2009, xxv, 341 s. ISBN 978-1-4302-2417-4.

Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí bakalářské práce: **Ing. Jakub Hendrych**

Datum zadání: 01.09.2016

Datum odevzdání: 28.04.2017



doc. Dr. Ing. Eduard Sojka
vedoucí katedry



prof. RNDr. Václav Snášel, CSc.
děkan fakulty

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně. Uvedl jsem všechny literární
prameny a publikace, ze kterých jsem čerpal.

V Ostravě 20. dubna 2017

Michal Škrobly.....

Souhlasím se zveřejněním této bakalářské práce dle požadavků čl. 26, odst. 9 Studijního a zkušebního řádu pro studium v bakalářských programech VŠB-TU Ostrava.

V Ostravě 20. dubna 2017

.....*Mark Škrobáň*.....

Ďakujem vedúcemu svojej bakalárskej práce Ing. Jakubovi Hendrychovi za podporu, rady a konzultácie pri tvorbe práce. Ďalej by som chcel poďakovať prof. Ing. Lačezarovi Ličevovi, CSc., prof.h.c., MUDr. Jaroslavovi Havelkovi a MUDr. Olge Zapletalovej za pomoc pri záležitostiach týkajúcich sa medicíny. Moja vďaka nepochybne patrí aj mojej rodine a priateľom za trpezlivosť a podporu pri písaní tejto práce.

Abstrakt

Cieľom tejto bakalárskej práce je návrh a realizácia nástroja pre spracovanie obrazu v programe FOTOM^{NG}. Nástroj má slúžiť k spracovaniu snímok magnetickej rezonancie. Konkrétne pri roztrúsenej skleróze. Celý modul bude naprogramovaný v jazyku Java vo vývojovom prostredí NetBeans a naimplementovaný do systému FOTOM^{NG}. Výsledný algoritmus vyberie najvhodnejšiu segmentačnú metódu na základe metrík kvality skúmanej snímky. Segmentačné metódy, z ktorých bude vyberať, sú parametrické aktívne kontúry a Level Set. Taktiež prebehne predspracovanie obrazu. Bude použitý prevod do stupňov šedej, mediánová filtrácia a sobelov filter. Na záver bude zhodnotená úspešnosť vybraných segmentačných metód. Teoretická časť tejto práce sa bude zaoberať roztrúsenou sklerózou, magneticou rezonanciou, fotogrametriou, systémom FOTOM^{NG}, riešeniami tohto problému vo svete a všeobecným rozdelením segmentačných metód. Cieľom práce je zároveň navrhnuť užívateľskú príručku a programátorskú dokumentáciu.

Kľúčové slová: FOTOM^{NG}, JAVA, magnetická rezonancia, segmentačná metóda, roztrúsená skleróza, spracovanie obrazu, aktívne kontúry, Level Set

Abstract

The goal of this bachelor's thesis is to design and accomplish a tool for image processing using FOTOM^{NG} program. The tool is supposed to be used for processing of magnetic resonance imaging, specifically of sclerosis multiplex. The whole module will be programmed in the Java programming language in the software development platform NetBeans and will be implemented into the system FOTOM^{NG}. The final algorithm will select the most suitable segmentation method based on the quality metrics of the examined image. It will select from the segmentation methods which are parametric active contours and Level Set. Image pre-processing will also take place. Converting an image to grayscale, median filtering and sobel filtering will be used. At the end the success of the selected segmentation methods will be assessed. The theoretical part of this thesis will deal with sclerosis multiplex, magnetic resonance, photogrammetry, the system FOTOM, solutions of this problem in the world and the general division of the segmentation methods. The goal is also to conceive a user manual and programming documentation.

Key Words: FOTOM^{NG}, JAVA, magnetic resonance, segmentation method, sclerosis multiplex, image processing, active contours, Level Set

Obsah

Zoznam použitých skratiek a symbolov	9
Zoznam obrázkov	10
Zoznam tabuliek	11
1 Úvod	13
2 Roztrúsená skleróza	14
3 Magnetická rezonancia	15
3.1 História MRI	15
3.2 Princíp MRI	15
4 Fotogrametria a systém FOTOM	16
4.1 FOTOM 2008	16
4.2 FOTOM ^{NG}	16
5 Segmentačné metódy	17
5.1 Prahovanie	17
5.2 Detekcia hrán	18
5.3 Level Set	23
6 Riešenie používané vo svete	27
7 Spracovanie v systéme FOTOM^{NG}	28
7.1 Zaradenie modulu „fotom-sclerosisdetection“ do systému	28
7.2 Výpočet metrík kvality a výber najvhodnejšej segmentačnej metódy	29
7.3 Predspracovanie obrázka	30
7.4 Segmentácia plakov roztrúsenej sklerózy	31
8 Testovanie	38
9 Záver	39
Literatúra	40
Prílohy	42
A Zoznam príloh	42

Zoznam použitých skratiek a symbolov

2D	– Two Dimensions - dvojrozmerný
3D	– Three Dimensions - trojrozmerný
API	– Application Programming Interface
DVD	– Digital Versatile Disc
GVF	– Gradient Vector Flow
ID	– Integrated Development Environment
JAI	– Java Advanced Imaging
LoG	– Laplacian of Gaussian
MR	– Magnetická rezonancia
MRI	– Magnetic Resonance Imaging
MSE	– Mean Squared Error
NG	– Next Generation
PDF	– Portable Document Format
PSNR	– Peak signal to noise ratio
RS	– Roztrúsená skleróza
SNR	– Signal to noise Ratio
SSIM	– Structural Similarity Index
XML	– Extensible Markup Language

Zoznam obrázkov

1	Level Set funkcia	23
2	Pôvodná snímka(vľavo), snímka po použití mediánového filtra(vpravo)	31
3	Pôvodná snímka(vľavo), snímka po použití sobelovho filtra(vpravo)	31
4	Ponuka po stlačení pravého tlačidla pri aktívnych kontúrach	33
5	Použitie segmentácie aktívnymi kontúrami	34
6	Použitie segmentácie aktívnymi kontúrami - priblíženie	34
7	Ponuka po stlačení pravého tlačidla pri Level Set	36
8	Použitie segmentácie Level Set	37
9	Použitie segmentácie Level Set - priblíženie	37

Zoznam tabuliek

1	Náhľad na tabuľku ukazujúcu porovnanie úspešnosti segmentačných metód. . . .	38
2	Tabuľka ukazujúca úspešnosť jednotlivých segmentačných metód	43
3	Tabuľka ukazujúca úspešnosť jednotlivých segmentačných metód. Pokračovanie .	44

Zoznam výpisov zdrojového kódu

1	Parametre algoritmu aktívnych kontúr	32
2	Parametre algoritmu Level Set	35

1 Úvod

V dnešnej dobe sú moderné zobrazovacie metódy v medicíne na vysokej úrovni a neustále sa zlepšujú. Aj vďaka tomu sú lekári schopní včas diagnostikovať a v mnohých prípadoch aj vyliečiť ochorenia, ktoré boli v minulosti často rozsudkom smrti.

V snahe pomôcť doktorom pri ich neľahkej úlohe sa na Vysoké škole báňské v Ostrave neustále vyvíja systém FOTOM^{NG} pôvodne navrhnutý na premeriavanie dolných jám. Prvá verzia programu bola výsledkom diplomovej práce pána Ing. Holušu pod vedením pána prof. Ing. Lačezara Ličeva, CSc., prof.h.c.. Vďaka metódam naimplementovaným do tohto systému vznikol nástroj, užitočný pre lekárov, umožňujúci zobrazovať presnejšie a lepšie oblasti, ktoré potrebujú skúmať. V systéme FOTOM^{NG} je umožnené spracovávať snímky ultrasonické, röntgenové, snímky z počítačovej tomografie aj z magnetickej rezonancie.

Práve spracovaním snímok z magnetickej rezonancie sa bude zaoberať aj táto práca. Konkrétne skúmaním príznakov roztrúsenej sklerózy. Je to ochorenie napádajúce mozog a príznaky môžu byť veľmi nevyspytateľné. Viac informácií o tejto zákernej chorobe a o tom ako funguje bude možné nájsť v druhej kapitole. Tretia kapitola bude popisovať magnetickú rezonanciu, jej princíp a históriu.

V ďalšej kapitole sa budú nachádzať informácie o samotnom systéme FOTOM, pretože je jednou z mojich úloh spomínaný systém rozšíriť o nový modul na detekciu roztrúsenej sklerózy. V ideálnom prípade by tento modul mal pomôcť lekárom pri diagnostike tohto ochorenia a čo najviac zjednodušiť ich prácu. Všetky úkony, u ktorých to bude možné, sa pokúsim naimplementovať tak, aby sa vykonávali automaticky. Patria tam činnosti ako skúmanie snímky, výber najvhodnejšej segmentačnej metódy vzhľadom na konkrétny obrázok, nastavenie parametrov tejto metódy a ďalšie. Pre doktorov, ktorí nemusia mať tento typ znalostí, môžu byť určité úkony neprehľadné.

V piatej kapitole sa budem zaoberať všeobecne segmentáciou obrazu a predovšetkým tými metódami, ktoré v rámci tejto práce naimplementujem. Ďalšia kapitola by sa mala týkať riešení tohto problému vo svete. Budem študovať postupy odborníkov zaoberajúcich sa touto problematikou.

Potom v praktickej časti bude nasledovať popis môjho postupu pri implementovaní nového modulu a testovaní jednotlivých segmentačných metód.

Dôvodov prečo som sa rozhodol zvoliť si práve tuto tému ako bakalársku prácu je niekoľko. V prípade úspešného zrealizovania by vytvorený modul mohol pomôcť lekárom s diagnostikou a tým aj ľuďom, ktorí touto strašnou chorobou trpia. Ďalším dôvodom je môj osobný záujem o medicínu a veci, ktoré s ňou súvisia.

2 Roztrúsená skleróza

Roztrúsená skleróza je choroba postihujúca centrálny nervový systém. Jej príčina nie je doposiaľ známa, preto jej nie je možné predchádzať a ani dodnes nebol objavený liek, ktorý by bol schopný úplne zastaviť postup tohto ochorenia. Postihuje prevažne ľudí medzi 20. až 40. rokom života.

K lepšiemu pochopeniu tejto choroby je potrebné zjednodušiť vysvetliť, ako funguje centrálny nervový systém. Myelin je tuková substancia obaľujúca, chrániaca a vyživujúca nervové vlákna. Bez tejto izolácie nervové vlákna po čase odumierajú. Myelinový obal obklopuje axony, predĺžené výbežky nervových buniek, zaisťujúce prenos signálu medzi nervovými bunkami. Na týchto vláknach sú sodíkové a draslíkové kanáliky veľmi dôležité pre prenos elektrického impulzu po nervovom vlákne. Nie všetky nervové vlákna sú obalené myelinom, pretože myelin je náročný na priestor. Preto myelin obklopuje len tie axony, ktoré musia viesť vzruchy rýchlo, napríklad ku svalom. Axony riadiace vnútorné orgány nemusia byť také rýchle a preto myelin neobsahujú.

Názov roztrúsená skleróza je priliehavé pomenovanie. Slovo „skleróza“ je z gréckeho slova skleros, ktoré sa prekladá ako tuhý. Dôvodom je, skutočnosť, že po odznení zápalu sa postihnuté tkanivo zjazví. Označenie „roztrúsená“ je použité preto, lebo zápalové ložiská vznikajú na rôznych miestach. Nazývajú sa tiež plaky alebo lézy. Ložiská môžu mať rôznu veľkosť. Niekoľko milimetrov až centimetrov. Sú rozsiate v bielej hmote mozgu a miechy. Dochádza tam k rozpadu myelinu. RS je autoimunitné ochorenie. Imunitný systém považuje myelin za škodlivý a preto ho ničí. Po zničení ochranného myelinu chorobným procesom je prenos nervových vzruchov spomalený alebo úplne prerušený. Organizmus často tento problém kompenzuje nahromadením väčšieho množstva draslíkových a sodíkových kanálikov, takže impulz môže pokračovať v ceste ako u nemyelizovaného axonu. Nervové vlákna sú dokonca schopné znovuoobnovenia myelinových obalov. Prebiehajúci zápal ale túto regeneráciu oddŕaľuje a znovu obnovený myelin už nie je taký silný, takže vedenie impulzov môže byť obnovené, ale je pomalšie. [1]

3 Magnetická rezonancia

Je to metóda, ktorá dokáže zobrazit morfológické známky poškodenia centrálného nervového systému. Roztrúsenú sklerózu na obraze MRI charakterizuje výsev mnohopočetných ložísk v bielej hmote v priestore a čase. Za patologické prejavy RS sú považované ložiská zvýšeného signálu v móde flair a v T2W obraze. Niekedy majú korelát zníženého signálu v T1W obraze. [2]

3.1 História MRI

Magnetická rezonancia je pomerne novodobá technika. Jej počiatky siahajú do roku 1920, keď bol na základe teoretických úvah predpovedaný jav MRI. Ale až o tridsať rokov neskôr nastal samotný objav nukleárnej magnetickej rezonancie. Bol objavený vedcami Purcellom a Blochom, ktorí boli odmenení Nobelovou cenou. Prvý prístroj, ktorý využíval magnetickú rezonanciu bol vynájdený o rok neskôr. Nebol však určený pre lekárske použitie. Potom nastal rozsiahly rozvoj. V 60. rokoch dvadsiateho storočia sa začala využívať Fourierová transformácia. Napomohlo to ku zvýšeniu citlivosti MR. Potom v sedemdesiatich rokoch sa boli využité supravodivé magnety. Bol to obrovský prelom v tejto oblasti. Od deväťdesiatich rokov sa rozvíjajú 3D metódy a rôzne ďalšie kombinované metódy MRI. [3]

3.2 Princíp MRI

Nukleonové číslo vyjadruje počet protónov a neutrónov v jadre. Protóny aj neutróny majú vlastný moment hybnosti, ktorému hovoríme spin. Pre magnetickú rezonanciu sú dôležité prvky s nepárnym nukleonovým číslom ako napríklad vodík. Keďže je ľudské telo tvorené zo 70 % vodou, je umožnené lekárske požadované zobrazenie.

Princíp MRI funguje nasledovne. V okolí elektrického prúdu sa nachádza magnetické pole meniace sa s veľkosťou elektrického prúdu. Pri nabitých časticách ako u MRI sa jedná o magnetický moment. Ak sa zmení magnetický moment, tak sa indukuje prúd na cievkach magnetickej rezonancie. Magnetické momenty vodíka majú v tkanivách iný smer, preto sú spiny vodíka uvedené do statického magnetického poľa (B_0). Tu sa usporiadajú do paralelných a antiparalelných pozícií a začnú precesiu. To je rotácia spinov v transversálnom smere. [4]

4 Fotogrametria a systém FOTOM

Fotogrametria je vedný a technický odbor, zaoberajúci sa meraním na fotogrametrických snímkach a spracovaním takto získaných informácií. Základom fotogrametrie ako meracej techniky je skutočnosť, že fotografická snímka je za určitých podmienok exaktným stredovým priemetom fotografovaného predmetu. Existujú teda jednoznačné geometrické vzťahy medzi skúmaným predmetom a jeho obrazom, ktoré je možné numericky, graficky alebo mechanicky určiť pomocou špeciálnych prístrojov. Fotografické snímky sa dajú týmito prístrojmi taktiež premerať a zmerané údaje spracovať a vyhodnotiť. Samozrejme nie každá snímka je vhodná pre účely fotogrametrie. Kvalitná fotogrametrická snímka musí byť vyhotovená zvláštnym aparátom so špeciálnym vybavením, napríklad fotografickou meračskou komorou. [5]

4.1 FOTOM 2008

Program FOTOM, slúžiaci k digitálnemu spracovaniu snímok sa od roku 2000 vyvíja na katedre informatiky FEI VŠB TU Ostrava. Pôvodne bol navrhnutý na meranie dolných jám, ale časom sa rozšíril na systém s mnohými modulmi. Poskytuje pokročilé možnosti detekcie záujmových objektov. Staršia verzia FOTOM 2008 mala tieto moduly:

Modul FOTOM1 – slúži k definícii záujmových objektov, ktoré sa dajú ďalej merať, modelovať a dá sa sledovať ich vývoj. Tento modul umožňuje definovanie bodu, vrcholu, hrany, kružnice, elipsy a polygónu.

Modul FOTOM2 – používa sa na 2D modelovanie objektov. Umožňuje porovnávať merania a sledovať odchýlky.

Modul FOTOM3 – je to modul pre vizualizáciu meraní. Zostaví zo série snímok 3D model, s ktorým je jednoduché manipulovať a vykonávať ďalšie merania.

Modul FOTOM4 – slúži k animácii procesu merania. Umožňuje užívateľovi prezentovať merania aj iným spôsobom ako len grafom. Výsledná animácia zobrazuje priebeh sledovaným objektom.

Modul FOTOM5 – používa sa k nájdeniu a automatickému definovaniu sledovaného objektu podľa predchádzajúcich snímok. Aj zložitý objekt je nájdený na novej snímke a označený. [6]

4.2 FOTOM^{NG}

Cieľom bolo vytvoriť systém, ktorý by bol modulárny, vyvíjaný modernými technológiami a akákoľvek úprava alebo pridanie modulu bolo čo najjednoduchšie. Začali na tom pracovať vtedajší diplomanti Ing. Lukáš Krahulec a Ing. Ján Král.

Tento systém je vyvíjaný v programovacom jazyku Java a vo vývojovom prostredí Netbeans platform, vďaka ktorému je umožnená modularita. Obsahuje jednotlivé API, ktoré môže použiť každý novo pridaný modul bez nutnosti zásahu do zdrojového kódu. Z FOTOMU 2008 bola väčšina funkcionality prevedená do novej verzie. [7]

5 Segmentačné metódy

Predpokladajme, že máme obraz a naším cieľom je rozpoznať objekty v tomto obraze. Prvým krokom je extrakcia objektov nachádzajúcich sa na tomto obraze. Tento proces, v ktorom sú objekty separované od nezaujímavého pozadia sa nazýva segmentácia obrazu. Je to komplexný proces skladajúci sa z niekoľkých krokov. Vstupný obraz je väčšinou potrebné nejakým spôsobom upraviť. Napríklad odstrániť šum. Po prvotnom predspracovaní nasleduje samotná segmentácia. Najčastejšie je založená na detekcii hrán ohraničujúcich jednotlivé objekty alebo na detekcii celých oblastí, ktorými sú jednotlivé objekty reprezentované. V tejto práci sa podrobnejšie venujem problematike segmentácie a jej využitiu predovšetkým pri spracovaní medicínskych snímok. [8, 9]

5.1 Prahovanie

Prahovanie je pokladané za najjednoduchšiu metódu segmentácie. V prípadoch, ktoré nie sú príliš komplikované sa pritom jedná o metódu rýchlu a spoľahlivú. Výsledkom prahovania je binárny obraz. Pixelom nájdených objektov v tomto obraze je obvykle priradená hodnota 1, zatiaľ čo zvyšným pixelom, čiže pixelom pozadia, je priradená hodnota 0. Vychádza sa z predpokladu, že body hľadaných oblastí majú rovnaký alebo veľmi podobný jas. Jedna z možností zrealizovania prahovania funguje tak, že pixel je označený ako bod hľadaného objektu, ak jeho jas padne do vopred stanoveného intervalu. Dosť často je v rozhodovacom kritériu použitá iba jedna hodnota, takzvaný prah. Body, ktoré majú hodnotu jas vyššiu ako hodnota prahu, sú označené ako body hľadaných oblastí a body, ktorých hodnota jas je nižšia, sú označené za body pozadia, poprípade naopak. Teda funguje to na základe tohto predpisu:

$$f(x, y) = \begin{cases} 1, & f(x, y) \geq T \\ 0, & f(x, y) < T \end{cases}$$

Úspešnosť prahovania je závislá predovšetkým na poznaní správnej hodnoty prahu. Ak hodnotu prahu nepoznáme, môžeme sa ju pokúsiť stanoviť na základe informácií získaných z obrazu, na ktorý prahovanie aplikujeme. Pre bimodálny histogram, čiže taký histogram, ktorý má dva vrcholy, sa často doporučuje zvoliť ako hodnotu prahu hodnotu, v ktorej dosahuje histogram medzi obidvomi vrcholmi minimum. Predpokladá sa totiž, že v obraze existujú dva druhy pixelov: pixely, ktoré prislúchajú hľadaným oblastiam a pixely, ktoré prislúchajú pozadiu. Oba tieto druhy sú relatívne početné a majú dosť rozdielny jas, čo v histograme spôsobuje vznik dvoch spomínaných vrcholov. Ak nie sú tieto predpoklady splnené, tak výsledky metódy nemusia byť uspokojivé. Histogram taktiež nemusí byť vždy bimodálny.

V určitých prípadoch, keď je obraz síce kontrastný, no v rôznych častiach má nerovnomernú úroveň jas, nedá sa často nájsť jedna hodnota prahu tak, aby vyhovovala pre všetky časti obrazu. V takom prípade sa dá použiť prahovanie s premennou hodnotou prahu, kde sa pre

rôzne miesta v obraze používajú rôzne hodnoty prahu. Táto metóda sa dá realizovať tak, že sa obraz rozdelí na viacero častí a pre každú časť sa nájde individuálna hodnota prahu. Ak je histogram úrovne jasu skúmanej oblasti obrazu bimodálny, je možné určiť hodnotu prahu popísaným spôsobom. [8]

Existuje viacero variant prahovania. Najznámejším typom prahovania je globálne prahovanie, pri ktorom je pre celý obraz použitý rovnaký prah. Medzi globálne prahovanie sa dá zaradiť aj percentuálne prahovanie. Tu sa zadáva ako prah percentuálne zastúpenie bodov v obraze. Vhodné môže byť napríklad pri skenovaní textu, ak vieme, že text tvorí určité percento na stránke.

Ďalej je tu viacstupňové prahovanie. Obraz sa dá rozdeliť na viac ako dve disjunktné množiny. Pixel je priradený hľadanému objektu ak jeho hodnota leží medzi dvoma určenými prahmi.

Pri hystereznom prahovaní sú za objekty označené tie oblasti, ktorých intenzita je väčšia ako nejaký prah T_1 a obsahujú aspoň jeden pixel s intenzitou väčšou ako prah T_2 . [9]

5.2 Detekcia hrán

Skúsme si predstaviť, že každý objekt v obraze je reprezentovaný súvislou oblasťou. Všetky oblasti sú obklopené hranicami. Hranice pozostávajú z hrán a hrany sa skladajú z jednotlivých bodov. Hrany odpovedajú prudkým zmenám hodnôt jasu. Hlavnou myšlienkou detekcie hrán je nájdenie miest v obraze, kde sa jas výrazne mení. [8, 10]

Pri riešení hľadania hrán sa postupuje často tak, že sa najskôr vyhľadajú jednotlivé body hrán. Tieto nájdené body sú potom rôznymi technikami spojované do hrán a celých hraníc. Problém môže nastať pri šume. Jeho vplyvom môžu byť hrany detegované aj tam, kde nie sú. [8]

5.2.1 Metódy segmentácie založené na prvej derivácii

Tieto metódy detekcie hrán využívajú skutočnosť, že v mieste hrany má absolútna hodnota prvej derivácie priebehu jasu vysokú hodnotu, zatiaľ čo v homogénnych oblastiach je zmena hodnoty jasu a teda aj prvá derivácia rovná nule. Hodnota derivácie, ktorá popisuje intenzitu kontúry v danom bode sa nazýva veľkosť hrany. Operátory stanovujúce veľkosť hrany, ktoré sa aplikujú v každom bode obrazu sa nazývajú hranové operátory.

Metódam využívajúcim prvú deriváciu sa hovorí aj gradientné. Ak vypočítame parciálne derivácie podľa x a y , získame vektor udávajúci veľkosť a smer gradientu. Gradient $\nabla g(i, j)$ je vektor, ktorý je kolmý na vektor udávajúci smer hrany. Uhol, ktorý hrana zvierá s osou ψ a veľkosť hrany $|\nabla g(i, j)|$ sa dajú vypočítať podľa vzorcov:

$$|\nabla g(i, j)| = \sqrt{\left(\frac{\partial g}{\partial x}\right)^2 + \left(\frac{\partial g}{\partial y}\right)^2} \quad (1)$$

$$\psi = \arctg \left(\frac{\frac{\partial g}{\partial y}}{\frac{\partial g}{\partial x}} \right) \quad (2)$$

Derivácie pre diskretnú obrazovú funkciu sa počítajú ťažko, preto je ich nutné aproximovať vhodným výpočtom diferenciálu. Najčastejšie je na výpočet diferenciálu používaná centrálna diferenciálna rovnica (3), v ktorej O udáva rád chyby výpočtu.

$$\nabla f(x) = \frac{f(x+1) - f(x-1)}{2h} + O(h^2) \quad (3)$$

Častejšie používaným spôsobom výpočtu je už spomínaný hranový detektor. Ak prevedieme konvolúciu s určitým jadrom, ako výsledok získame hľadajú zložku gradientu.[9, 8]

Robertsov operátor je jeden z najstarších hranových operátorov. Veľkosť hrany sa počíta podľa predpisu:

$$e(x, y) = \sqrt{(f(x, y) - f(x+1, y+1))^2 + (f(x+1, y) - f(x, y+1))^2} \quad (4)$$

Operátor Prewittové používa k výpočtu veľkosti hrany hodnoty obrazovej funkcie vo všetkých okolitých pixelov. Tieto hodnoty si označme A,B,C,D,E,F,G,H,I. Operátor počíta derivácie vo smere osi x a y . Výpočet môžeme vidieť na vzorci (5).

$$\begin{aligned} fx(x, y) &= \frac{1}{3}[(C - A) + (F - D) + (I - G)] \\ fy(x, y) &= \frac{1}{3}[(A - G) + (B - H) + (C - I)] \end{aligned} \quad (5)$$

Tento postup prispieva k redukcii šumu na obraze. Sobelov operátor je veľmi podobný Prewittovej operátoru. Rozdiel je v tom, že sa pre výpočet derivácii v jednotlivých smeroch používa vážený priemer podľa vzorca (6).

$$\begin{aligned} fx(x, y) &= \frac{1}{4}[(C - A) + 2(F - D) + (I - G)] \\ fy(x, y) &= \frac{1}{4}[(A - G) + 2(B - H) + (C - I)] \end{aligned} \quad (6)$$

U Kirschovho operátora je derivácia počítaná celkom v ôsmich smeroch a veľkosťou hrany sa stáva jej maximálna hodnota. Okolité pixely počítaného bodu si označme A1 až A7. Výsledná veličina je vypočítaná pomocou vzorca (7).

$$\begin{aligned} e(x, y) &= \max_{0 \leq i \leq 7} [|5S_i - 3T_i|] \\ S_i &= A_i + A_{(i+1)} + A_{(i+2)} \end{aligned} \quad (7)$$

Cannyho detektor hrán je navrhnutý tak, aby spĺňal určité požiadavky. Tými požiadavkami je minimalizovať pravdepodobnosť chybnjej detekcie, nájsť polohu hrany v obraze čo najpresnejšie a bod hrany identifikovať jednoznačne. Algoritmus je nasledovný. Na začiatku sa vytvorí konvolučné jadro Gaussového filtra pre následnú elimináciu šumu. Potom sa obraz rozmaže v smere osi y a spočíta sa parciálna derivácia podľa osi x . Podobný postup je aj pri Sobelovom operátore, len veľkosť Gaussového filtra môže byť akákoľvek a derivácia sa nemusí počítať cez diferenciál. Rovnakým spôsobom sa počíta aj ypsilonová zložka gradientu. Ak poznáme obidve zložky je jednoduché vypočítať veľkosť gradientu podľa vzorca (8).

$$|g| = \sqrt{g_x^2 + g_y^2} \quad (8)$$

Pretože po výpočte prvej derivácie vznikajú tučné hrany a našim cieľom je, aby bola hrana detegovaná iba tam, kde sa skutočne nachádza, tak je nutné vykonať stenčenie hrán. Toto stenčenie sa vykonáva pomocou poloprahovacej techniky nazývanej Nonmaxima suppression. Vychádza sa z predpokladu, že hrana dáva väčšiu odozvu v mieste, kde sa skutočne nachádza. Tento krok ale rozpojí hrany na miestach, kde sa stretávajú tri hrany vytvárajú tvar T. Nakoniec sa snažíme eliminovať falošné a nevýznamné hrany. Hysterezné prahovanie ponechá len tie hrany, ktorých gradient aspoň v niektorých miestach dosahuje požadovanú veľkosť. Výsledná mapa hrán obsahuje aj neuzavreté hrany.[9, 8]

5.2.2 Metódy segmentácie založené na druhej derivácii

Druhá derivácia priebehu jasnosti nadobúda v smere naprieč hranou dva extrémne opačné znamienka a v mieste hrany sa znamienko mení. Teda v mieste, v ktorom dochádza k najväčšej zmene intenzity a prvá derivácia je najväčšia, druhá derivácia prechádza nulou. Tento postup môžeme použiť v prípade, že nutne nepotrebujeme poznať smer a veľkosť hrán a vystačíme si iba s informáciou, kde sa hrany nachádzajú.

Ak chceme hrany vyhľadať, musíme najskôr vypočítať druhú deriváciu obrazovej funkcie a potom detegovať miesta, v ktorých dochádza k prechodu nulou. Samotnú druhú deriváciu je možné vypočítať použitím prvej derivácie dvakrát. Pre diskretnú funkciu sa počíta druhá derivácia pomocou rovnice (9).

$$\Delta^2 f(x) = \frac{f(x+1) - f(x-1)}{2h} + O(h^2) \quad (9)$$

Ďalšou z možností je použiť niektorý z hranových operátorov počítajúcich druhú deriváciu.

Laplacianové operátory patria do rodiny takzvaných LoG operátorov. Čo je skratka pre Laplacian of Gaussian. Ako konvolučné jadro využívajú vhodnú aproximáciu druhej derivácie Gaussového filtra. Gaussov filter je vyjadrený v rovnici (10) a jeho druhá derivácia v rovnici (11).

C v rovnici je normalizačný člen zaistujúci, aby výsledné konvolučné jadro malo súčet svojich elementov rovný nule.

$$G(x, y) = e^{-\frac{x^2+y^2}{\sigma^2}} \quad (10)$$

$$G''(x, y) = c^{-\frac{x^2+y^2-\sigma^2}{\sigma^4}} e^{-\frac{x^2+y^2}{\sigma^2}} \quad (11)$$

Výhodou LoG je možnosť zvoliť veľkosť jadra, ktorá má vplyv na jeho citlivosť. Čím je jadro väčšie, tým je odolnejšie voči šumu. Nevýhodou je ich neseparabilita. So zväčšujúcim sa jadrom rýchlo rastie aj časová náročnosť výpočtu konvolúcie s týmto jadrom. Možnosťou ako sa vyhnúť výpočtovej náročnosti je použitie filtra LoG. Obraz sa rozmaže dvakrát filtrom. Raz väčším a raz menším a výsledné obrazy sa od seba odčítajú.

Dalším operátorom je Marr a Hildreth operátor. Marr a Hildreth zistili, že pomer obrazov 1,6 dáva vynikajúcu aproximáciu filtru LoG. Dalším krokom je vytvoriť mapu hrán. Inými slovami nájsť miesta, kde druhá derivácia prechádza nulou. Jedným z postupov je hľadať body v ktorých dochádza ku zmene znamienka. Vytvorí sa maska s veľkosťou 2x2, ktorú postupne prikladáme na všetky body obrazu. Prvok a vpravo hore sa pokladá za stred masky. Je porovnaný s ostatnými prvkami. V prípade, že sa znamienko a líši od znamienok ostatných prvkov tak je daný bod označený za hranový.

$$\begin{bmatrix} a & b \\ c & d \end{bmatrix}$$

Metódy druhej derivácie majú na rozdiel od metód prvej derivácie nevýhodu vo vyššej citlivosti na šum a môžu mať aj vyššiu časovú náročnosť ale mapa hrán obsahuje iba tenké a uzavreté hrany.[9]

5.2.3 Aktívne kontúry

Aktívne kontúry našli vysoké uplatnenie pri segmentácii medicínskych obrazov, ktoré bývajú často poškodené šumom alebo vzorkovacími artefaktami. Ide o deformovanú krivku vnútri obrazu, ktorá je deformovaná vplyvom obrazových síl. Na krivku pôsobia vonkajšie a vnútorné obrazové sily. Vnútorné sily slúžia k udržaniu hladkosti priebehu, obrazové sily sa zaoberajú tvarovaním kontúr smerom ku hranám obrazu a vonkajšie sily závisia na pôvodnom umiestnení kontúry, teda sú zadane užívateľom.

Aktívna kontúra môže byť reprezentovaná diskretnou sadou bodov:

$$v_n = [x_n, y_n], pre \quad n = 0, 1, \dots, N,$$

kde v ... je bod krivky,

x ... je x-ová súradnica bodu v ,

y ... je y-ová súradnica bodu v.

Aktívna kontúra môže byť definovaná aj ako parametrická krivka:

$$v(s) = [x(s), y(s)], pre \quad s \in [0, 1] \quad (12)$$

Výsledná pozícia aktívnej kontúry je určená pomocou energetickej funkcie definovanej:

$$E_{snake} = \int_0^1 E_{snake}(v(s))ds = \int_0^1 [E_{internal}(v(s)) + E_{image}(v(s)) + E_{con}(v(s))]ds \quad (13)$$

kde $v(s)$ je parametrická krivka, s je dĺžka krivky, $E_{internal}$ je vnútorná energia, E_{image} je vonkajšia energia a E_{con} je vonkajšie obmedzenie ako aproximácia krivky jej druhou deriváciou.

$E_{internal}$ je vnútorná energia, vzhľadom k zakriveniu krivky v prvej a v druhej derivácii. Je to súčet ohýbacej energie a elastickej energie. Vypočítame ju podľa vzorca:

$$E_{internal} = \frac{1}{2} \int_s (\alpha(s)|v_s|^2 + \beta(s)|v_{ss}|^2)ds \quad (14)$$

Za zmršťovanie kontúry je zodpovedná elastická energia. Váhová funkcia $\alpha(t)$ definuje hladkosť kontúry podľa vzťahu:

$$E_{internal} = \frac{1}{2} \int_s \alpha(s)|v_s|^2ds \quad kde \quad v_s = \frac{dv(s)}{ds} \quad (15)$$

Ohýbacia energia s váhovou funkciou $\beta(t)$ definuje pružnosť kontúry podľa vzťahu:

$$E_{bending} = \frac{1}{2} \int_s \beta(s)|v_{ss}|^2ds \quad (16)$$

Vonkajšia energia sa skladá z troch zložiek a vypočíta sa podľa vzorca:

$$E_{bending} = W_{line}E_{line} + W_{edge}E_{edge} + W_{term}E_{term} \quad (17)$$

E_{line} predstavuje príťažlivosť kontúry ku svetlým alebo tmavým častiam kontúry obrazu podľa príslušného váhového faktoru W_{line} .

$$E_{line} = f(v(s)) \quad (18)$$

E_{edge} priťahuje kontúry k miestam s vysokou hodnotou gradientu teda ku hranám. Vypočíta sa podľa vzorca:


$$E_{edge} = -|\nabla f(v(s))|^2 \quad (19)$$

Najzložitejšou zložkou je E_{term} . Jeho úlohou je detegovať ostré rohy a konce hrán pomocou skúmania krivosti. Krivosť sa počíta na rozmazanom obraze kvôli predpokladanému šumu. Táto hodnota býva malá, ak sa kontúra pohybuje po rovnej, hladkej hrane.

E_{con} predstavuje externé sily definované užívateľom, slúžiace k znázorneniu jeho interaktívnych požiadavkou. [11]

5.3 Level Set

Level Set je metóda určovania hraníc medzi oblasťami a funguje na podobnom princípe ako aktívne kontúry. Tiež je tu treba manuálne inicializovať jednotlivé body kontúry. Samotná krivka je reprezentovaná takzvanou nulovou hladinou – rezom v rovine xy nejakou viacdimeziálnou funkciou. Táto viacdimeziálna funkcia je nazývaná level set function a každému bodu na rovine xy priradí jeho výšku u nad nulovou hladinou ako vidno na obrázku 1.1. Povrch funkcie sa postupne adaptuje vzhľadom k obrazovému gradientu a zadaným metrikám krivosti. Hlavný rozdiel medzi level setom a aktívnymi kontúrami spočíva v tom, že tvar krivky nemeníme priamo ale pomocou level-set funkcie.



Obr. 1: Level Set funkcia

Výhodou level set segmentácie je jej výpočtová rýchlosť, pamäťová nenáročnosť a možnosť použitia na detekciu parametricky nepopísaných objektov. Je možnosť segmentovať viacero objektov zároveň. Vďaka týmto prednostiam sú tieto metódy používané v medicíne pri segmentovaní dát z MRI a CT. [12, 11]

Ako vlastne funguje Level Set segmentácia? Zo začiatku je hladká uzavretá krivka $v(0)$ v Euklidovskom priestore. Funkcia $v(q)$ ponúka množinu kriviek tak, ako sa vyvíja v čase q z počiatočnej $v(0)$ pod vplyvom síl F . Body nachádzajúce sa na krivke $v(q)$ sú dané funkciou $v(q, t)$ pre $t \in (0, S)$. Krivka môže byť reprezentovaná bodmi, s ktorými sa dá pohybovať v drobných diskretných krokoch. Ďalšou možnosťou je chápať $v(q)$ pre pevné q ako podmnožinu nadroviny $\psi(x, q) : R^N \rightarrow R$, ktorá je daná rovnicou $\psi(v, q) = 0$. Počiatočná krivka má tvar $v(q = 0) = x | \psi(x, q = 0) = 0$. Takže namiesto počítania samotnej krivky v obraze, sa počíta nadrovina ψ a krivka v sa od nej odčíta až vtedy, keď ju treba zobrazíť. Hranica objektu teda krivka $v(q)$ je implicitne zadaná výrazom $\psi(v, q) = 0$. Podobne ako u aktívnych kontúr ide

o vývoj funkcie pod vplyvom síl odvodených z analyzovaného obrazu a poprípadne vnútorných vlastností ako je krivosť alebo derivácia. Problémom je ako nadefinovať nadrovinu $\psi(v, q)$ a sily, ktoré s ňou budú pohybovať.

Najskôr sa zavedie $\psi(v, q) = 0$ ako najkratšia vzdialenosť bodu x od krivky $v(0)$. Potom teda pre $x \in R^N$ platí:

$$\psi(x, t = 0) = \pm d \quad (20)$$

Znamienko pred d je záporné, ak sa bod x nachádza vnútri uzavretej krivky vo vzdialenosti d . Ak je znamienko kladné, tak bod x sa nachádza vonku od uzavretej krivky vo vzdialenosti d .

Ak chceme odvodiť rovnicu pre výpočet nadroviny ψ začneme u definície $x(q), q \in [0, \infty)$ ako polohy bodu na krivke funkcie ψ závislej na čase. Bod $x(0)$ je bod počiatkovej krivky. Ak sa táto funkcia dosadí do rovnice nadroviny ψ , vyjde nasledujúca podmienka:

$$\psi(x(q), q) = 0 \quad (21)$$

Hodnota ψ sa v $(x(q), q)$ v čase nemení. Deriváciou dostaneme vzorec:

$$\frac{\partial \psi}{\partial q} + \frac{\partial \psi}{\partial x} \frac{\partial x}{\partial q} = \frac{\partial \psi}{\partial q} + \sum_{i=0}^n n \frac{\partial \psi}{\partial x_i} \frac{\partial x_i}{\partial q} \quad (22)$$

Do tejto rovnice je dosadený výraz odvodený z obrazových dát. Najlepšie sa vyjadří veľkosť rýchlosti bodu nadroviny. Teda zmeny polohy v čase v smere normály. Môžeme ju označiť F . Pre funkciu, ktorá je implicitne definovaná v tvare $f(x, y) = 0$, platí, že normála tejto funkcie je daná gradientom ∇f . Ak $\partial x / \partial q$ je zmena polohy bodu x v čase a $\nabla \psi$ normála ψ v bode x potom veľkosť rýchlosti vo smere normály sa vypočíta:

$$F = |\partial x / \partial q| \left(\frac{\nabla \psi}{|\nabla \psi|} \frac{\partial x / \partial q}{|\partial x / \partial q|} \right) = \frac{\nabla \psi}{|\nabla \psi|} \partial x / \partial q \quad (23)$$

Kosínus pri skalárnom súčte dvoch jednotkových vektorov hovorí, ako veľmi sa smer pohybu bodu x podieľa v rovine na pohybe v smere normály. Túto veľkosť rýchlosti vyjadríme vzťahom:

$$\frac{\partial \psi}{\partial x} \frac{\partial x}{\partial q} = \left| \frac{\partial \psi}{\partial x} \right| \frac{\partial \psi / \partial x}{|\partial \psi / \partial x|} \frac{\partial x}{\partial q} F \quad (24)$$

Dosadením rovníc dostaneme:

$$\frac{\partial \psi}{\partial q} + \left| \frac{\partial \psi}{\partial x} \right| F = 0 \quad (25)$$

Tento výraz je parciálna-diferenciálna rovnica. Hodnoty funkcie ψ sú aproximované v diskretnom raste delenom uniformne v x a y krokom veľkosti h a v q krokom Δq . Hľadané hodnoty

sú $\psi(ih, jh, n\Delta q)$. Ak nahradíme derivácie diferenciami dostaneme:

$$\frac{\psi_{ij(n+1)} - \psi_{ijn}}{\Delta q} + |\nabla \psi_{ijn}| F(x(n\Delta q)) = 0$$

$$\nabla \psi_{ijn} = \left(\frac{\frac{\psi_{(i+1)jn} - \psi_{ijn}}{h}}{\frac{\psi_{i(j+1)n} - \psi_{ijn}}{h}} \right) \quad (26)$$

Zostáva nám formulovať F . Táto hodnota je rozdelená na dve komponenty F_A a F_G . F_A je veľkosť sily zabezpečujúca neustály pohyb hranice. F_G je veľkosť sily vychádzajúca z geometrie hranice a starajúca sa o jej vyhladenie.

$$\frac{\partial \psi}{\partial q} + \left| \frac{\partial \psi}{\partial x} \right| F_A(x(q)) + \left| \frac{\partial \psi}{\partial x} \right| F_G(x(q)) = 0 \quad (27)$$

Ak za F_G dosadíme 0 namiesto F_A , sa definuje nová sila F_1 , ktorá pôsobí proti F_A a zároveň je riadená obsahom obrazu.

$$F_1 = \frac{-F_A}{M_1 - M_2} (|\nabla G_{\partial} * f(x, y)| - M_2) \quad (28)$$

M_1 a M_2 sú maximum a minimum gradientu vyhladeného obrázku $\nabla G_{\partial} * f(x, y)$. F_1 v tomto prípade môže nadobúdať hodnoty od $-F_A$ po 0. F_1 dosahuje minimum teda $-F_A$ v tom mieste, kde je najsilnejšia hrana. Teda platí, že $F = 0$ a hrana sa na takom mieste zastaví. Ak je M_1 maximálne, teda platí $F_1 = 0$ hrana sa posunie v smere normály silou F_A .

Pri použití vyhladzovacej sily F_G sa obidve nenulové sily F_A a F_G vynásobia hodnotou k_1 .

$$k_1(x, y) = \frac{1}{1 + |\nabla G_{\partial} * f(x, y)|} \quad (29)$$

Výraz k_1 v miestach, kde je vysoký gradient nadobúda hodnôt blízkych nule. Tam, kde je intenzita obrazu skoro konštantná, sa blíži k jednotke. K nule sa k_1 blíži v tvare:

$$k_1(x, y) = e^{|\nabla G_{\partial} * f(x, y)|} \quad (30)$$

Termíny F_1 a k_1 sa vzťahujú iba na nultú hladinu. Preto, ak ich rozšírime na celú ψ , vzniknú rozšírené \hat{F}_1 a \hat{k}_1 . Rovnica pre plochu má tvar:

$$\frac{\partial \psi}{\partial q} + \hat{F}_1 \left| \frac{\partial \psi}{\partial x} \right| = 0 \quad (31)$$

$$\frac{\partial \psi}{\partial q} + \hat{k}_1 (F_A + F_G) \left| \frac{\partial \psi}{\partial x} \right| = 0 \quad (32)$$

Pre funkciu \hat{F}_1 musí platiť rovnosť s pôvodnou funkciou F_1 na nulte hladine. Mimo nulte hladiny sa dá funkcia dodefinovať napríklad hodnotou sily F_1 najbližšieho bodu na vrstevnici nulte hladiny.

Keď si zhrnieme algoritmus Level Set, tak nám vznikne nasledujúci postup. Vstupná krivka $v(q = 0)$ tvorí vrstevnicu nulte hladiny. V druhom kroku je konštruovaná mriežka hodnôt funkcie $\psi(x, q = 0)$: hodnoty na krivke v sú nastavené na nulu a hodnoty mimo krivku sú inicializované vzdialenosťou najbližšieho bodu krivky. Vzdialenosť sa počíta kladná pre body mimo krivky a záporná pre body vnútri krivky. V treťom kroku je konštruovaná \hat{F} pre všetky body mriežky. V kroku štyri je mriežka updatovaná podľa rovnice (26). Ďalej v kroku päť je konštruovaná nová kontúra $v(q)$ z mriežky ψ . V šiestom kroku sa overuje konvergenčné kritérium. Ak nie je splnené tak sa pokračuje s $(n+1)$. krokom od tretieho kroku pre $q = (n + 1)\Delta q$.

Je pravdepodobné, že nulové hodnoty sa po štvrtom kroku v mriežke vyskytovať nebudú. Rekonštrukcia kontúry sa urobí v priebehu priechodu mriežky nájdením bodov, v ktorých sa mení znamienko oproti susedom. Za hraničný bod sa dá určiť ten bod, ktorého sused v 4-okolí alebo 8-okolí je opačného znamienka. Presnejší výsledok sa dá získať bilineárnou interpoláciou. [13]

5.3.1 Narrow-band

Súčasťou algoritmu je konštrukcia funkcie rýchlostí \hat{F} tak, že hodnota $v(x, y)$ sa rovná hodnote v najbližšom bode vrstevnice nulte hladiny. Pre každý bod mriežky sa hľadá najbližší bod na krivke $v(q)$. V praxi to môže byť pomalé. Preto bolo potrebné nájsť spôsob ako algoritmus urýchliť. Jedným riešením je definovať si úzky pásik okolo hladiny nulte úrovne a updatovať \hat{F} a ψ v priebehu každého kroku len v ňom a raz za čas v závislosti na šírke pásika, reinicializovať ψ na celom obraze.

5.3.2 Fast Marching Level Set

Fast Marching Level Set je snaha urýchliť segmentáciu Level Set. Predpokladá, že hodnota F má na celom svojom obore rovnaké znamienko. Buď je všade záporná alebo všade kladná. Spôsob akým sa správa algoritmus sa dá predstaviť tak, že hranice oblastí sa šíria ako hranice rozlievajúcej sa kvapaliny. Nevracia sa nikdy späť a neustupuje zo zaplaveného územia. Vďaka tomu sa dá zúžiť narrow-band na šírku jedného pixela v smere šírenia. V priebehu šírenia vlny sa mení aj narrow-band. Vždy, keď je pixel narrow-bandu zaplavený, sú do narrow-bandu pridaní jeho susedia. To, ktorý pixel má byť zaplavený, je dané najmenšou hodnotou funkcie $T(x, y)$. Táto funkcia má význam času, v ktorom sa vlna dostane nad bod (x, y) . Splňa podmienku $|\nabla T|F = 1$.

Funkcia T je na začiatku inicializovaná len v narrow-bandu počiatkovej krivky. Potom sa dopočítava pre všetky nové body narrow-bandu. Vďaka tomuto zjednodušeniu sa namiesto prechádzania plochy prechádzajú iba body krivky. Platí pravidlo, že v priebehu celého výpočtu je každý bod obrazu navštívený len raz. [13]

6 Riešenie používané vo svete

Rozhodol som sa porovnať moju prácu s inými prácami podobného typu vo svete. Ako prvý som vybral článok v International Journal of Advanced Research in Computer Science and Software Engineering zverejnený v máji roku 2015. Autorom je S.M. AliAsmaa Maher. Bol využitý nasledujúci postup. Na začiatku je prevedený obrázok s MR pomocou prahovania a zvolenia vhodného prahu do binárneho formátu. V ďalšom kroku je využitá metóda narastania oblastí a vyhľadávania takzvaných semienok. Nasleduje detekcia hrán a oddeľovanie jednotlivých oblastí. Boli použité rôzne detektory hrán. Napríklad Laplacianov detektor alebo Marr and Hildreth detektor. Gaussov filter sa v tomto prípade ukázal ako efektívny nástroj k odstráneniu šumu.[14]

Iný článok v International Journal of Advanced Research in Computer Science and Software Engineering zverejnený v roku 2014 sa taktiež zaoberá problémom analýzy snímku MR a detekciou roztrúsenej sklerózy. Autormi článku sú vedci zo Sri Vidya College of Engineering and Technology. V prvom kroku je nasadený medián filter slúžiaci k odstráneniu šumu. Medián filter je nelineárny filter, často používaný v spracovaní obrazu, pretože zachováva hrany. K detekcii hrán je použitý Sobelov operátor. Je využitá Bayesianová klasifikácia a algoritmus random forest. Týmito technikami boli schopní pomerne presne detekovať aj lézy malej veľkosti.[15]

Na 13th International Conference on Research in Telecommunication Technologies 2011 bol prezentovaný výskum týkajúci sa automatického segmentovania lézy na mozgu. Na začiatku segmentácie sa odstránia všetky nežiaduce oblasti z mozgu ako oči, čeluste a ďalšie. Ponechajú sa len tie časti u ktorých je možný výskyt lézy roztrúsenej sklerózy. Keď sú nežiaduce časti odstránené, nasleduje samotná segmentácia. Ako prvá bola testovaná metóda založená na hľadaní oblastí Watershed. Je efektívna pri obrázkoch, ktoré neobsahujú šum. Druhou bola K-mean clustering method. Ďalej bola použitá level set funkcia. Je založená na riešení parciálnych diferenciálnych rovníc. Vytvorí krivku obklopujúcu objekt. Testované boli segmentačné algoritmy the Random Forest algorithm, Support Vector Machines (SVM) algorithm, k-Nearest Neighbours algorithm, Naive Bayes Networks algorithm, One R algorithm, a Artificial Neural Network algorithm. Ako najspoľahlivejší sa v tomto testovaní ukázal Random Forest algorithm.[16]

7 Spracovanie v systéme FOTOM^{NG}

Táto kapitola je zameraná na vytvorenie nového modulu fotom-sclerosisdetection, ktorý sa dá zaradiť do systému FOTOM^{NG} tak, aby využíval všetky dostupné prvky tohto systému. Cieľom nového modulu je pomôcť užívateľovi s identifikáciu plakov RS na biomedicínskych snímkach z magnetickej rezonancie. Pomocou viacerých metrík boli zistené vlastnosti jednotlivých obrázkov a následne na základe týchto vlastností vybraná najvhodnejšia segmentačná metóda. Segmentačné metódy implementované v rámci tejto diplomovej práce sú parametrické aktívne kontúry a Level Set metóda. Okrem týchto metód je použité aj vhodné predspracovanie obrazu. Po samotnej segmentácii záujmových oblastí môžu byť použité nástroje na zmeranie obsahu nájdených plakov roztrúsenej sklerózy. Vývoj tohto modulu prebiehal v jazyku Java vo vývojovom prostredí NetBeans IDE 8.2. Kvôli správnej činnosti, rýchlosti a jednoduchšej implementácii sú v systéme nainštalované knižnice a aplikácia JAI.

7.1 Zaradenie modulu „fotom-sclerosisdetection“ do systému

Pri zaradení nového modulu do systému som sa snažil zachovať doterajšie trendy programovania systému FOTOM^{NG}, vďaka čomu je úprava jednotlivých modulov prehľadnejšia a jednoduchšia.

Tento nový modul bol pridaný pod názvom fotom-sclerosisdetection. Štruktúra modulu je rozdelená do troch balíčkov. Sú to balíčky org.fotomapp.sclerosisdetection, org.fotomapp.sclerosisdetection.activecontour a org.fotomapp.sclerosisdetection.levelset. Prvý balíček obsahuje triedu Bundle, ktorá je nevyhnutná pre vytvorenie českých aj anglických názvov toolov. Sú tu tiež vytvorené dva XML dokumenty. Dôležité je vytvorenie takzvanej layer.xml, ktorá definuje súbory a zložky, ktoré majú byť zlúčené do súborového systému a tvorí tak informačnú runtime konfiguráciu NetBeans s jeho modulmi. V balíčku nazývanom org.fotomapp.sclerosisdetection.activecontour sa nachádza implementácia segmentačnej metódy nazývanej parametrické aktívne kontúry. V tomto balíčku sú štyri triedy. Z dôvodu zjednodušenia použitia tejto segmentačnej metódy boli do modulu v priebehu realizácie pridané ďalšie dva balíčky org.magicwerk.brownies.collections a org.magicwerk.brownies.collections.functions, ktoré sa ukázali ako potrebné pri spustení parametrických aktívnych kontúr.

V ďalšom balíčku, ktorý sa nazýva org.fotomapp.sclerosisdetection.levelset je naimplementovaná segmentačná metóda Fast Marching Level Set. Rovnako ako v prvom balíčku sa tu tiež nachádza trieda Bundle nevyhnutná pre pomenovanie interakcii s užívateľom. Sú tu dve triedy v ktorých je naprogramovaný samotný segmentačný algoritmus. Potom sa tu nachádzajú ďalšie dve triedy AddIterationsPanel a EndAlgorithmPanel, ktoré slúžia na kontrolovanie postupu algoritmu užívateľom.

Vytvorený model je zostavený takým spôsobom, že na začiatku sú vypočítané jednotlivé metriky kvality obrazu a následne na základe hodnôt týchto metrík je vybraná najvhodnejšia segmentačná metóda. V rámci automatického predspracovania je obraz prevedený do odtieňov

šedej, na odstránenie šumu je použitý mediánov filter a na zvýraznenie hrán v obraze Sobelov filter. Predspracovanie obrazu prebehne automaticky s použitím zmeraných vlastností obrazu.

Až po úprave je užívateľovi poskytnutá jedna z dvoch možností. Buď segmentácia parametrickou aktívnou kontúrou alebo metódou Fast Marching Level Set. Po samotnej segmentácii je možné vytvoriť objekt polygón potrebný k následnému zmeraniu obsahu jednotlivých plakov na snímkach MR.

7.2 Výpočet metrík kvality a výber najvhodnejšej segmentačnej metódy

Pri algoritme určenia najvhodnejšej segmentačnej metódy som počítal viacero rôznych metrík kvality obrazu. Spolu je týchto metrík viac ako desať. Veľká časť slúži na určenie šumu na obraze, potom na výpočet kontrastu, jasú a ďalších vlastností snímok.

7.2.1 Metriky slúžiace na určenie šumu

SNR alebo pomer signálu k šumu je hodnota pomáhajúca určiť množstvo šumu na obraze. Je to pomer signálu a šumu. Pri výpočte tejto metriky je potrebné mať k dispozícii dve snímky. Na získanie druhej snímky som použil medianový filter s hodnotou masky 3. Týmto spôsobom vznikla druhá snímka s čiastočne odstráneným šumom, ktorý je možné použiť pri výpočte SNR. Pri porovnaní pôvodnej snímky a snímky s odstráneným šumom je možné zistiť hodnotu šumu.

Ďalšou použitou metrikou je MSE alebo stredná kvadratická chyba. Jej hodnota sa používa pri výpočte metriky PSNR alebo obrysu pomeru signálu ku šumu. Použil som celkom dve PSNR metriky.

Jednou z použitých metrík je aj SSIM index alebo structural similarity index vyjadrujúci podobnosť dvoch obrazov. Jedná sa o metódu porovnávania, ktorá berie do úvahy, že ľudské videnie je vysoko prispôbené k extrahovaniu štruktúrálnej informácie. Je to určitý spôsob určenia kvality obrazu. Nadobúda hodnotu od -1 po 1, kde hodnota jedna znamená vysokú kvalitu. Aj pri tejto metrike sú potrebné dva obrázky k prevedeniu výpočtu. Použil som rovnaký postup ako pri ostatných metrikách. Takže som využil medianový filter a s hodnotou masky 3 a takto získaný obrázok som použil pri výpočte.

Pri výpočte SSIM indexu som v prvom kroku použil Gaussov filter s veľkosťou jadra 11 na pôvodný obrázok aj na obrázok upravený medianovým filtrom. V ďalšom kroku sú vytvorené tri obrázky. Dva z nich sú vytvorené ako druhé mocniny pôvodných hodnôt jasú dvoch obrázkov, ktoré vznikli po použití Gausového filtru a tretí ako súčin týchto dvoch obrázkov. Vzniknuté tri obrázky sú použité k samotnému výpočtu SSIM indexu.

Pri určovaní šumu som použil ešte 3 metriky. Jednu z nich som nazval noise. Na výpočet hodnoty tejto metriky je potrebné vytvoriť konvolúčne jadro o veľkosti 5 a dvakrát prejsť celý obraz. Pri prvom priechode sa počíta priemerná hodnota pre každý pixel a táto hodnota je využitá pri výpočte samotného šumu.

Druhú metriku som nazval sigma. Postup jej výpočtu je nasledujúci. V prvom kroku je prevedená konvolúcia s konvolučným jadrom o veľkosti 3x3. Na takto upravenom obrázku sa počíta suma absolútnych hodnôt jednotlivých pixelov obrázka, ktorá je následne využitá pri konečnom výpočte.

Poslednou metrikou, ktorá slúži k určeniu kvality obrazu je Ricianov šum. Je to šum, ktorý vzniká pri magnetickej rezonancii. Algoritmus výpočtu je ale pomerne komplikovaný a časovo náročný. Využívajú sa tu vlastnosti ako šikmosť, odchýlka a stredná hodnota. Je vytvorené konvolučné jadro a obrázok sa niekoľkokrát prechádza.

7.2.2 Metriky slúžiace na určenie jas a kontrastu

Do tejto skupiny metrík patrí metrika, ktorú som nazval brighnest alebo jas. Je to priemerný jas danej snímky. Potom tu patrí aj štandardná odchýlka alebo standart deviation. Slúži k určeniu kontrastu. Je získaná z histogramu. Medzi ďalšie metriky, ktoré som použil, patrí aj entropia, ktorá sa dá získať z histogramu a výška a dĺžka obrázka.

7.2.3 Výber najvhodnejšej segmentačnej metódy


V tomto konkrétnom prípade som pri výbere najvhodnejšej segmentačnej metódy použil iba dve možnosti a to parametrické aktívne kontúry a Fast Marching Level Set. Takže môj rozhodovací algoritmus vždy zvolí jednu zo spomínaných možností.

Pri určovaní sa berú do úvahy hodnoty väčšiny metrík, ktoré som použil. Tieto metriky sú rozdelené do skupín. Sú to skupiny: šum, jas a kontrast a entropia. Pre každú metriku použitú v rozhodovacom algoritme, sa zisťuje, či jej hodnota patrí do určitého vopred určeného intervalu. V prípade, že tam patrí, sa tak zvýši hodnota príslušného číselníka pre konkrétnu segmentačnú metódu. Každá skupina má svoje číselníky pre každú segmentačnú metódu. Na záver sa porovnávajú hodnoty číselníkov medzi jednotlivými skupinami a na základe ich hodnôt je vybraná najvhodnejšia segmentačná metóda.

7.3 Predspracovanie obrázka


Pred samotnou segmentáciou je potrebné obraz upraviť kvôli zvýšeniu účinnosti segmentačných metód. Ja som pri predspracovaní použil techniky na odstránenie šumu a na zvýraznenie hrán v obraze. Aktívne kontúry a Level Set sú celkom náchylne na šum.

Z toho dôvodu som použil mediánový filter. Filtrácia mediánovým filtrom patrí medzi nelineárne metódy filtrácie. Slúži k redukcii šumu a rozmazávania hrán. Nevýhodou je porušovanie tenkých čiar a ostrých rohov v obraze. Prevedenie tohto filtra je automatické. Veľkosť matice použitej pri výpočte je určená automaticky na základe veľkosti obrazu a množstva šumu na obraze.



Obr. 2: Pôvodná snímka(vľavo), snímka po použití mediánového filtra(vpravo)

Ďalším krokom bolo použitie sobelovho filtra. Je využitý z dôvodu zvýraznenia hrán v obraze. Aplikuje sa automaticky pred použitím konkrétnej segmentačnej metódy. Jeho použitie vidno na nasledujúcom obrázku:



Obr. 3: Pôvodná snímka(vľavo), snímka po použití sobelovho filtra(vpravo)

7.4 Segmentácia plakov roztrúsenej sklerózy

Po automatickom predspracovaní obrazu a výpočte jeho metrík kvality nasleduje výber konkrétnej segmentačnej metódy. Ako bolo už spomínané, sú na výber dve metódy: parametrické aktívne kontúry a Fast Marching Level Set. Obidve tieto metódy sú poloautomatické, takže vyžadujú manuálnu inicializáciu užívateľom.

7.4.1 Realizácia metódy parametrických aktívnych kontúr

Ako jedna z dvoch segmentačných metód, ktoré môžu byť zvolené, bola vybraná a do systému FOTOM^{NG} naimplementovaná metóda parametrických aktívnych kontúr. Táto metóda sa už v určitej forme v systéme FOTOM^{NG} nachádzala, ale bola upravená tak, aby bola pri segmentácii plakov RS čo najúčinnnejšia. Predovšetkým boli zmenené jej vstupné parametre. Tieto parametre sa menia aj automaticky vzhľadom k veľkosti skúmanej snímky. Slúžia k ovplyvňovaniu samotnej kontúry. Zdrojový kód parametrov pre parametrické aktívne kontúry vo vývojovom prostredí NetBeans je nasledujúci:

```
private Color paintColorLine = Color.RED;
private Integer sizeLine = 2;
private Color paintColorPoint = Color.YELLOW;
private Integer sizePoint = 3;
//parametry algoritmu aktivnich kontur
private Integer adaptIter = 1; //po kolika it dojde k adaptaci bodu //10
private Integer minLeg = 1; //minimalni delka segmentu //8
private Integer maxLeg = 6; //maximalni delka segmentu //16
public Double alpha = -13.0;
private Double beta = 3.0;
private Double gamma = -23.0;
private Double kappa = 47.0;
private Integer maxIter = 500; //1000
//parametry GVF
private Integer gvfiIteration = 25; //pocet iteraci GVF //25
private Double mu = 0.1; //parametr Mu
```

Výpis 1: Parametre algoritmu aktívnych kontúr

- **Alpha** – udáva pružnosť kontúry
- **Beta** – parameter ovplyvňujúci ohybnosť kontúry
- **Gamma** – hodnota ovplyvňujúca viskozitu kontúry
- **Kappa** – hodnota určujúca váhu externej energie
- **Iterace kontury** – parameter určujúci maximálny počet iterácií, hodnota je určená tak, aby bola rozpoznaná nehybnosť kontúry, teda že je kontúra umiestnená v lokálnom minime, ďalšie iterácie už nie sú potrebné a výpočet môže byť ukončený
- **Iterace GVF** – určuje počet iterácií pri výpočte externej energie GVF
- **Mu** – parameter udávajúci regulačný koeficient

- **Minimální délka segmentu** – určuje minimální vzdialenosť medzi dvomi bodmi
- **Maximální délka segmentu** – hodnota určujúca maximálnu vzdialenosť medzi dvomi bodmi
- **Adaptace po iteraciích** – po zadanom počte iterácii prevedie automaticky novú inicializáciu bodov na kontúre; je potrebný preto, lebo dochádza k naťahovaniu kontúry a tým aj k vzdalovaniu bodov od seba
- **Barva – křivky**
- **Barva – bodu**
- **Tloušťka – křivky**
- **Tloušťka – bodu**


Nástroj parametrické aktívne kontúry je vybraný automaticky. Je možné ho použiť až po úprave snímky. Inicializačná krivka je prevediteľná držaním ľavého tlačidla myši a od začiatku je uzatvorená. Po nakreslení inicializačnej krivky stačí kliknúť pravým tlačidlom a ukáže sa kontextová ponuka s výberom položiek pre parametrické aktívne kontúry:

Inicializace kontury	I
Spustit	C
Nová inicializační křivka	N
Uložit segmentaci	S
Vytvořit polygon	P


Obr. 4: Ponuka po stlačení pravého tlačidla pri aktívnych kontúrach

- **Inicializace kontury** – je dostupná v prípade, že je nakreslená inicializačná krivka; ostatné položky sú dostupné až po inicializácii
- **Spustit** – týmto sa spustia výpočty na základe vstupných parametrov
- **Nová inicializační křivka** – táto položka je dostupná len vtedy, ak už je nakreslená inicializačná krivka; zmaže pôvodne nakreslenú krivku a umožní tak užívateľovi nakresliť krivku nanovo
- **Uložit segmentaci** – daná segmentácia sa uloží a natrvalo zakreslí do obrazu.
- **Vytvořit polygon** – zo segmentácie je vytvorený objekt polygón, s ktorým je možné ďalej pracovať

Na snímke, ktorá sa nachádza dole, bola prevedená segmentácia s pomocou parametrických aktívnych kontúr. Snímka bola pred tým predspracovaná. Najskôr bola prevedená do stupňov šedej. Následne bola vykonaná mediánová filtrácia na odstránenie šumu a vyhladenie obrazu. Potom bol použitý sobelov filter na zvýraznenie hrán. Nakoniec som vďaka funkcii Reset Image v systéme FOTOM^{NG} zobrazil pôvodný obrázok.



Obr. 5: Použitie segmentácie aktívnymi kontúrami



Obr. 6: Použitie segmentácie aktívnymi kontúrami - priblíženie

7.4.2 Realizácia metódy Fast Marching Level Set

Fast Marching Level Set je druhá zo segmentačných metód, ktoré môžu byť automaticky vybrané na základe analýzy metrík obrazu. U tejto metódy na začiatku prebehne rýchla segmentácia Fast Marching a potom pre dokončenie a vyladenie klasická metóda Level Set. Rovnako ako parametrické aktívne kontúry aj táto metóda bola v systéme FOTOM^{NG} naimplementovaná, ale bola upravená tak, aby sa stala čo najvhodnejšou pre naše účely. Zmenené boli aj parametre tejto funkcie. Niektoré sú zadané a niektoré sa menia na základe vlastností obrázka. Zdrojový kód parametrov pre Fast Marching Level Set vo vývojovom prostredí NetBeans je nasledujúci:

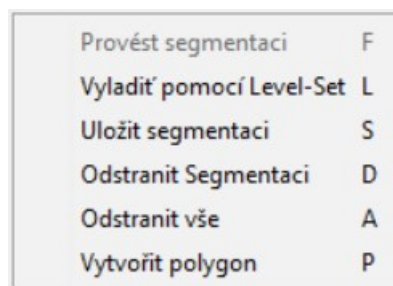
```
// NASTAVITELNE PROMENNE TOOLU
private Integer marchingIter = 2;
private Double marchingCoeff = 70.0;
private Integer innerIter = 1;
private Integer outerIter = 2;
private Double levelsetTimeStep = 0.001;
private Integer bandwidth = 6;
private Double curvature = 0.025;
private Double attraction = 0.01;
private Color paintColorLine = Color.RED;
private Integer sizeLine = 1;
private Color paintColorPoint = Color.RED;
private Integer sizePoint = 1;
```

Výpis 2: Parametre algoritmu Level Set

- **Iterace Fast Marching** – parameter udávajúci maximálny počet iterácií
- **Fast Marching exponent** – používa sa pri výpočte rýchlosti; v ideálnom prípade by táto rýchlosť v oblasti hrany mala byť rovná nule
- **Vnitřní iterace Level Set** – parameter určujúci maximálny počet vnútornej slučky v ktorej dochádza k prepočítaniu phi
- **Vnější iterace Level Set** – parameter určujúci maximálny počet iterácií vonkajšej slučky; po každej iterácii sa znovu inicializuje hodnota phi a narrow band; k doladeniu a dosiahnutiu dobrého výsledku stačí iba niekoľko iterácií, pretože tento proces je časovo náročný
- **Časový krok Level Set** – rozhoduje sa medzi kvalitou obrysu a rýchlosťou prevedenia
- **Šírka pásma Level Set** – parameter využívaný pre zrýchlenie výpočtu hodnoty phi
- **Ohebnosť krivky Level Set**

- **Hodnota ovlivňující výpočet přílnavosti**
- **Barva – křivky**
- **Barva – bodu**
- **Tloušťka – křivky**
- **Tloušťka – bodu**

Metóda Fast Marching Level Set je poloautomatická. Uživatel vloží inicializačné body do záujmových oblastí a stlačí pravé tlačidlo myši pre zobrazenie kontextovej ponuky.




Obr. 7: Ponuka po stlačení pravého tlačidla pri Level Set


- **Provést segmentaci** – táto ponuka je dostupná iba v prípade, že užívateľ zvolil aspoň jeden inicializačný bod na snímke; jej stisnutím je spustená segmentácia; ostatné položky sú dostupné až po prevedení segmentácie
- **Vyladit pomocí Level Set** – spustí sa ladenie pomocou Level Set
- **Uložit segmentaci** – rovnako ako pri metóde parametrických aktívnych kontúr je segmentácia trvalo vykreslená do obrazu.
- **Odstranit segmentaci** – segmentácia je odstránená, ale sú ponechané užívateľom zadané inicializačné body
- **Odstranit vše** – odstráni aj segmentáciu aj inicializačné body
- **Vytvořit polygon** – vďaka tejto ponuke je vytvorený objekt polygón, s ktorým je možné ďalej pracovať

Po tom ako užívateľ zadá inicializačné body, sa spustí segmentácia, ktorá je obmedzená počtom iterácií. Je potrebné nastaviť jednotlivé iterácie pri každej segmentácii snímky. Keď sú vykonané nastavené iterácie, automaticky sa zobrazí okno, ktoré sa opýta, či chce užívateľ pridať ďalšie iterácie. Ak je spokojný zo segmentáciu môže toto okno zatvoriť.

Na nasledujúcej snímke bola prevedená segmentácia s pomocou Fast Marching Level Set. Snímka bola pred tým predspracovaná. Na začiatku bola prevedená do stupňov šedej. Následne bola vykonaná medianová filtrácia na odstránenie šumu a vyhladenie obrazu. Potom bol využitý sobelov filter na zvýraznenie hrán. Nakoniec som vďaka funkcii Reset Image v systéme Fotom zobrazil pôvodný obrázok. Je to obdobný postup ako pri parametrických aktívnych kontúrach.



Obr. 8: Použitie segmentácie Level Set



Obr. 9: Použitie segmentácie Level Set - priblíženie

8 Testovanie

Dáta, ktoré boli testované som získal od Ing. Jakuba Hendrycha a od prof. Ing. Lačezarovi Ličevovi, CSc., prof.h.c. Celkovo som otestoval 30 snímok a na nich 50 plakov roztrúsenej sklerózy. Boli použité T1, T2 a flair snímky. Pri testovaní som porovnával účinnosť naimplementovaných segmentačných metód. Výsledky segmentácie boli porovnávané s ručne vyznačenými plakmi. Lokalizácia prebiehala pomocou ručného nakreslenia polygónu v systéme FOTOM^{NG}. Je nutné brať do úvahy možné straty informácií a určitú nepresnosť vzhľadom k veľkosti testovaných snímok. Aj napriek tomu boli ručne označené oblasti brané ako referenčné.

Pri testovaní oboch segmentačných metód som použil predspracovanie obrazu spomínané v predchádzajúcich kapitolách. Určité nepresnosti pri testovaní vznikli pravdepodobne predovšetkým kvôli tomu, že testovacie snímky a aj samotné plakky na snímkach mozgu boli veľmi malé. Ďalším dôvodom môže byť to, že obe metódy sú poloautomatické a preto záleží aj na postupe užívateľa. Nasledujúca tabuľka 1 je náhľadom na tabuľku, ktorá ukazuje výsledky testovania pri porovnávaní obsahu označeného jednotlivými metódami v percentách. Použitie oboch metód na 50 plakov RS a ich účinnosť v percentách ukazuje tabuľka 2.

Tabuľka 1: Náhľad na tabuľku ukazujúcu porovnanie úspešnosti segmentačných metód.

Označenie plaku	Lokalizovaný ručne [px]	Segmentácia Fast Marching Level Set [px]	Percentuálna úspešnosť [%]	Segmentácia aktívnymi kontúrami [px]	Percentuálna úspešnosť [%]
1	22,5	16	71,11	23	97,83
2	21	16,6	78,57	22,5	93,33
3	47	55,5	84,68	40,5	86,17
4	4	4	100	7	57,14
5	4,5	4	88,89	6	75
6	16	16	100	22,5	71,11
7	17,5	17	97,14	18,5	94,59
8	29	30,5	95,08	30	96,67
9	4,5	5,5	81,81	4	88,89
10	6	4	66,67	7	85,71
11	2,5	4	62,5	2	80
12	9	8,5	94,44	9,5	94,74
13	9	8,5	94,44	7,5	83,33
14	8	9,5	84,21	10	80

9 Záver

Cieľom tejto práce bolo vytvoriť nový modul do systému FOTOM^{NG} umožňujúci spracovávať snímky z magnetickej rezonancie. Konkrétne snímky pacientov trpiacich roztrúsenou sklerózou. Snahou bolo čo najviac uľahčiť lekárom diagnostiku tejto choroby.

Na začiatku som musel dôkladne preštudovať a pochopiť fungovanie samotného systému FOTOM^{NG}. Program, na ktorom som pracoval, je napísaný v jazyku Java na platforme NetBeans. Bolo nevyhnutné získať aj dosť veľa teoretických znalostí ohľadom roztrúsenej sklerózy, magnetickej rezonancie a hlavne v oblasti týkajúcej sa segmentácie obrazu. Až po naštudovaní týchto potrebných znalostí bolo možné navrhnúť riešenie daného problému.

Rozhodol som sa použiť dve segmentačné metódy a to parametrické aktívne kontúry a Fast Marching Level Set. Pri použití oboch týchto metód je nutné určité predspracovanie obrazu. Využil som mediánový filter na odstránenie šumu a sobelov na zvýraznenie hrán. Mnou naimplementovaný algoritmus taktiež zisťuje viacero metrík skúmanej snímky a na základe hodnôt týchto metrík sa rozhoduje, ktorá segmentačná metóda bude použitá.

Metriky, ktoré som meral, sa týkajú predovšetkým kvality snímky, šumu na snímke ale aj ďalších vlastností ako jas a kontrast. Pre každú metriku použitú v rozhodovacom algoritme sa zisťuje, či jej hodnota patrí do určitého vopred určeného intervalu. V prípade, že tam patrí, sa tak sa zvýši hodnota príslušného číselníka pre konkrétnu segmentačnú metódu. Každá skupina metrík má svoje číselníky pre každú segmentačnú metódu. Nakoniec sa porovnávajú hodnoty číselníkov medzi jednotlivými skupinami a na základe ich hodnôt je vybraná najvhodnejšia segmentačná metóda.

Na záver som obe metódy otestoval. Dokopy som testoval 30 snímok a na nich 50 plakov roztrúsenej sklerózy. Určitým problémom bolo, že som žiaľ nemal k dispozícii snímky urobené inými zariadeniami alebo v inom formáte. Ďalej tieto snímky boli relatívne v malom rozlíšení, čo mohlo mať vplyv na presnosť segmentačných metód. Ako som zistil, tak pri reálnom použití sa využívajú snímky vo väčšom rozlíšení a predpokladám, že by jednotlivé metódy mali uspokojivo fungovať.

Ak porovnam moje riešenie s riešeniami vo svete, ktoré som skúmal, tak je v určitom ohľade flexibilnejšie. Ostatní použili rôzne metódy, ale neskúmali samotný obrázok, s ktorým pracovali.

Verím, že som splnil cieľ tejto bakalárskej práce, pretože som naštudoval, popísal a spracoval danú problematiku v zadanom rozsahu a dodržal zadanie práce. Moje riešenie je možné v budúcnosti rozšíriť o ďalšie metódy segmentácie prípadne vyvinúť až na systém na báze neurónových sietí.

Literatúra

- [1] *Co je to roztroušená mozkomíšní skleróza* [online]. [cit. 2017-02-13] Dostupné z: <http://www.ereska.cz/>
- [2] SEIDL, Zdeněk, Manuela VANĚČKOVÁ. *Magnetická rezonance hlavy, mozgu a páteře*. Vyd. 1. Praha: Grada Publishing a.s., 2007, 320 s. ISBN 978-80-247-1106-5
- [3] *Magnetická rezonance (1): Historie* Populárně naučný portál: POPULAR [online]. [cit. 2017-04-17] Dostupné z: <http://popular.fbmi.cvut.cz/biomedicina/Stranky/Magneticka-rezonance-1---Historie.aspx>
- [4] KOLÁŘOVÁ, Mariana. *Vývoj rozšíření nástrojů pro segmentaci a volumetrii tumoru mozku snímků v prostředí FOTOM^{NG} za účelem následného vyhodnocení zájmových objektů*. Ostrava, 2015. Diplomová práce. Vysoká škola Báňská – Technická univerzita Ostrava, Fakulta elektrotechniky a informatiky, Katedra Kybernetiky a Biomedicínského inženýrství.
- [5] LIČEV, Lačezar.: *Analýza, modelování, rozpoznávání a vizualizace procesu měření objektů na snímcích..* Vyd. 1. Brno:Computer Press a.s., 128 str., 2010. ISBN 978-80-2513-296-8, EAN 9788025132968
- [6] LIČEV, Lačezar, Lukáš KRAHULEC a Jan KRÁL. *Systém FOTOM 2009 na platformě NetBeans* [online]. 2010 [cit. 2017-01-10] Dostupné z: http://gisak.vsb.cz/GIS_Ostrava/GIS_Ova_2010/sbornik/Lists/Papers/CZ_1_8.pdf
- [7] KUZNÍK, Radek. *Analýza medicínských snímků za účelem registrace – vytvoření kvalitního snímku pro následné vyhodnocení*. Ostrava, 2013. Diplomová práce. Vysoká škola Báňská – Technická univerzita Ostrava, Fakulta elektrotechniky a informatiky, Katedra informatiky.
- [8] SOJKA, Eduard. *Digitální zpracování a analýza obrazů*. Ostrava: VŠB-TU Ostrava, Fakulta elektrotechniky a informatiky, 2000. ISBN 80-7078-746-5
- [9] STRAKA, Stanislav. *Segmentace obrazu*. Brno, 2009. Diplomová práce. Masarykova univerzita, Fakulta informatiky.
- [10] DOBEŠ, Michal. *Zpracování obrazů a algoritmy v C#*. Vyd. 1. Praha: BEN - technická literatúra, 2008, 143 s. ISBN 978-80-7300-233-6
- [11] ROMÁNEK, Jakub. *Metódy segmentace biomedicínských obrazových signálů v javě*. Brno, 2012. Diplomová práce. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ, FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ, ÚSTAV TELEKOMUNIKACÍ.
- [12] HORÁK, Karel, Illona KALOVÁ, Petr PETYOVSKÝ, Miroslav RICHTER, *Počítačové vidění*. Brno, 2008, VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ, FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ.

- [13] KRAJÍČEK, Václav. *Měření objemu v 3D datech*. Praha, 2007. Diplomová práce. UNIVERZITA KARLOVA V PRAZE, MATEMATICKO-FYZIKÁLNÍ FAKULTA, Kabinet software a vyuky informatiky.
- [14] MAHER, AliAsmaa. *Multiple Sclerosis Lesions Identification Technique Using MR Images* [online]. 2015 [cit. 2017-02-03], International Journal of Advanced Research in Computer Science and Software Engineering, ISSN: 2277 128X, Dostupné z: https://www.ijarcsse.com/docs/papers/Volume_5/5_May2015/V5I5-0230.pdf
- [15] VIDHYA, R., P. RAJARAJESWARI a S. ELLAMMAL. *Classification of Tissues for Detecting the MultipleSclerosis Lesions in Brain MRI* [online]. 2014 [cit. 2017-02-03] International Journal of Advanced Research in Computer Science & Technology (IJARCST 2014) Dostupné z: <http://docplayer.net/37030966-Classification-of-tissues-for-detecting-the-multiple-sclerosis-lesions-in-brain-mri.html>
- [16] BURGET, Radim, Ondrej SMIRG, Milos KERKOVSKY, Zdenek SMEKAL a Andrea SPRLAKOVA-PUKOVA. *Automatic segmentation of focal lesions in the brain, using artificial intelligence methods* [online]. 2011 [cit. 2017-02-05] 13th International Conference on Research in Telecommunication Technologies 2011 Dostupné z: <http://splab.cz/wp-content/uploads/2012/04/burget2011automatic.pdf>

A Zoznam príloh

Príloha 1 - Tabuľka ukazujúca úspešnosť jednotlivých segmentačných metód

Prílohy k tejto bakalárskej práci sú uložené na priloženom DVD, ktoré obsahuje:

1. Zdrojové kódy modulu sclerosisdetection
2. Zdrojové kódy systému FOTOM^{NG} s integrovaným modulom sclerosisdetection
3. Dokument samotnej bakalárskej práce ve forme PDF
4. Uživatelská príručka pre modul sclerosisdetection
5. Programátorská dokumentácia
6. Testovacie snímky

Tabuľka 2: Tabuľka ukazujúca úspešnosť jednotlivých segmentačných metód

Označenie plaku	Lokalizovaný ručne [px]	Segmentácia Fast Marching Level Set [px]	Percentuálna úspešnosť [%]	Segmentácia aktívnymi kontúrami [px]	Percentuálna úspešnosť [%]
1	22,5	16	71,11	23	97,83
2	21	16,6	78,57	22,5	93,33
3	47	55,5	84,68	40,5	86,17
4	4	4	100	7	57,14
5	4,5	4	88,89	6	75
6	16	16	100	22,5	71,11
7	17,5	17	97,14	18,5	94,59
8	29	30,5	95,08	30	96,67
9	4,5	5,5	81,81	4	88,89
10	6	4	66,67	7	85,71
11	2,5	4	62,5	2	80
12	9	8,5	94,44	9,5	94,74
13	9	8,5	94,44	7,5	83,33
14	8	9,5	84,21	10	80
15	6	5,5	91,67	6,5	92,31
16	9	6	66,67	8	88,89
17	6,5	6	92,31	5,5	84,62
18	7,5	6	80	6	80
19	6	5,5	91,67	5	83,33
20	10	5,5	55	9,5	95
21	7,5	5,5	73,33	8	93,75
22	7,5	5,5	73,33	4,5	60
23	5	7,5	66,67	6	83,33
24	9	8,5	94,44	7,5	83,33
25	9	9,5	94,74	7,5	83,33
26	6,5	8,5	76,47	7	92,86
27	8	8,5	94,12	7	87,5
28	5	6	83,33	6,5	76,92
29	16,5	12,5	75,76	17,5	94,29
30	9	5,5	61,11	8,5	94,44

Tabuľka 3: Tabuľka ukazujúca úspešnosť jednotlivých segmentačných metód. Pokračovanie

Označenie plaku	Lokalizovaný ručne [px]	Segmentácia Fast Marching Level Set [px]	Percentuálna úspešnosť [%]	Segmentácia aktívnymi kontúrami [px]	Percentuálna úspešnosť [%]
31	7,5	5,5	73,33	7,5	100
32	8	8	100	8,5	94,12
33	6	6	100	7,5	80
34	6,5	6	92,31	7,5	86,67
35	5	5,5	90,91	5,5	90,91
36	6	5,5	91,67	7	85,71
37	5	5,5	90,91	5	100
38	7,5	6	80	7,5	100
39	6	5,5	91,67	5,5	91,67
40	6	5,5	91,67	7	85,71
41	6	6	100	8	75
42	5	5,5	90,91	4	80
43	15	11,5	76,67	16	93,75
44	4	4	100	3,5	87,5
45	4	4	100	2	50
46	5	5,5	90,91	7	71,43
47	12	11,5	95,83	11,5	95,83
48	7	7	100	8,5	82,35
49	6	7	85,71	7	85,71
50	7	8,5	82,35	9	77,78